

4. Convergence en loi

La convergence en loi est une notion de convergence pour les variables aléatoires qui est plus faible que la convergence presque sûre, et qui capture l'idée suivante : $(X_n)_{n \in \mathbb{N}}$ converge en loi (ou en distribution) vers une variable X si les probabilités relatives à X_n (mais pas les valeurs de X_n) convergent vers les probabilités relatives à X . Pour des raisons topologiques, il faut faire un peu attention à la définition précise de convergence des probabilités. Les conditions suivantes s'avèrent être équivalentes pour une suite de variables aléatoires réelles $(X_n)_{n \in \mathbb{N}}$:

- (1) *Convergence des observables.* Pour toute fonction continue bornée $f : \mathbb{R} \rightarrow \mathbb{R}$,

$$\mathbb{E}[f(X_n)] \rightarrow_{n \rightarrow \infty} \mathbb{E}[f(X)].$$

- (2) *Convergence des probabilités.* Pour toute partie mesurable A telle que $\mathbb{P}[X \in \partial A] = 0$,

$$\mathbb{P}[X_n \in A] \rightarrow_{n \rightarrow \infty} \mathbb{P}[X \in A].$$

- (3) *Convergence des fonctions de répartition.* Pour tout point t tel que F_X soit continue en t ,

$$F_{X_n}(t) \rightarrow_{n \rightarrow \infty} F_X(t).$$

- (4) *Convergence des transformées de Fourier.* Pour tout réel ξ ,

$$\mathbb{E}[e^{i\xi X_n}] \rightarrow_{n \rightarrow \infty} \mathbb{E}[e^{i\xi X}].$$

On admettra l'équivalence de ces conditions, et on dira si elles sont vérifiées que $(X_n)_{n \in \mathbb{N}}$ converge en loi vers X (notation : $X_n \xrightarrow{n \rightarrow \infty} X$). Notons que si $(X_n)_{n \in \mathbb{N}}$ est une suite de variables aléatoires qui converge presque sûrement vers X , alors par le théorème de convergence dominée, on a convergence des observables : la convergence presque sûre est donc plus forte que la convergence en loi. Si les variables X_n et X sont à valeurs dans $\mathbb{Z}$, alors la convergence en loi est simplement donnée par :

- (5) *Convergence locale.* Pour tout $k \in \mathbb{Z}$,

$$\mathbb{P}[X_n = k] \rightarrow_{n \rightarrow \infty} \mathbb{P}[X = k].$$

Si $X \sim \mu$, on notera aussi la convergence en loi $X_n \xrightarrow{n \rightarrow \infty} \mu$.

1. Convergence vers la loi de Poisson.

On fixe un paramètre $\lambda > 0$ et on travaille avec des entiers $n \geq \lambda$.

- (1) Dresser les histogrammes empiriques de N tirages $X_1, \dots, X_N$ d'une loi binomiale $\text{Bin}(n, \frac{\lambda}{n})$ avec $N = 1000$, $n = 50, 1000$ et $\lambda = 1, 3, 5$. Comparer avec les histogrammes des lois de Poisson $\text{Poi}(\lambda)$.
- (2) Montrer avec le critère de convergence locale qu'on a effectivement $\text{Bin}(n, \frac{\lambda}{n}) \xrightarrow{n \rightarrow \infty} \text{Poi}(\lambda)$.
- (3) Donner une autre preuve reposant sur la convergence des transformées de Fourier.

2. Théorème central limite.

Le *théorème central limite* est un énoncé de convergence en loi pour la différence renormalisée entre une moyenne empirique de variables indépendantes et de même loi, et la moyenne théorique. Ainsi, si $X_1, X_2, \dots$ sont des variables indépendantes dont la loi commune μ admet un moment d'ordre 2 :

$$\int_{\mathbb{R}} x^2 \mu(dx) < +\infty,$$

et si $M_n = \frac{X_1 + X_2 + \dots + X_n}{n}$ et $m = \mathbb{E}[X_1]$, alors

$$\sqrt{n} \left(\frac{M_n - m}{\sigma} \right) \xrightarrow{n \rightarrow \infty} N(0, 1),$$

où

$$\sigma^2 = \left(\int_{\mathbb{R}} x^2 \mu(dx) \right) - \left(\int_{\mathbb{R}} x \mu(dx) \right)^2$$

désigne la variance de la loi μ , et $N(0, 1)$ est la loi gaussienne de densité $f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$ sur $\mathbb{R}$. La preuve repose sur le critère des transformées de Fourier, et sur le développement de Taylor $\mathbb{E}[e^{i\xi(X_1 - m)}] = \exp\left(-\frac{\sigma^2 \xi^2}{2} + o(1)\right)$.




FIG. 4.1. Densité et fonction de répartition de la loi normale $N(0, 1)$.

- (1) Écrire un programme qui tire un échantillon $(X_1, \dots, X_N)$ de variables aléatoires de même loi, et qui calcule le vecteur formée par toutes les moyennes recentrées et renormalisées :

$$\left(Z_n = \sqrt{n} \left(\frac{\frac{X_1 + \dots + X_n}{n} - m}{\sigma} \right) \right)_{n \in \llbracket 1, N \rrbracket}.$$

On pourra faire des essais avec différentes lois : par exemple, la loi uniforme sur $[0, 1]$, la loi exponentielle $\text{Exp}(1)$, et la loi de Bernoulli $\text{Ber}(\frac{1}{2})$.

- (2) Tracer pour la loi choisie le graphe de $n \mapsto Z_n$ pour $n \in \llbracket 1, 5000 \rrbracket$. A-t-on une convergence presque sûre ?
- (3) Tracer la fonction de répartition empirique d'un échantillon de $M = 1000$ variables Z_{1000} , et la comparer à la fonction de répartition de la gaussienne, qui est obtenue par la commande `scs.norm.cdf`.
- (4) On tire au hasard $p \in [0, 1]$ avec la commande `random.random()`, puis on observe des variables de Bernoulli $B_1, B_2, \dots, B_n$ de paramètre p , qui reste inconnu. À l'aide du théorème central limite, construire un *estimateur* $\hat{p}_n = \hat{p}_n(B_1, \dots, B_n)$ du paramètre p , puis un *intervalle de confiance* $[\hat{p}_{n,-}, \hat{p}_{n,+}]$ tel que

$$\lim_{n \rightarrow \infty} \mathbb{P}[p \in [\hat{p}_{n,-}, \hat{p}_{n,+}]] \geq 0.98.$$

Tester cet intervalle de confiance avec un échantillon de taille $n = 1000$.

La dernière question est la base théorique de la théorie des sondages.

3. Variables géométriques renormalisées.

Soit $\lambda > 0$ un paramètre fixé, et X_n une variable aléatoire géométrique de paramètre $p = \frac{\lambda}{n}$:

$$\mathbb{P}[X_n = k] = (1 - p)^{k-1} p \text{ pour tout entier } k \geq 1.$$

On pose $Y_n = \frac{X_n}{n}$.

- (1) Écrire un programme qui simule la variable Y_n . Dresser la fonction de répartition empirique de cette variable pour $n = 3, 10, 100$.
- (2) Comparer le cas $n = 100$ avec la fonction de répartition théorique d'une variable réelle de loi exponentielle $\text{Exp}(\lambda)$. Que peut-on conjecturer ?
- (3) Que vaut $\mathbb{P}[Y_n \geq s]$ pour $s \in \mathbb{R}_+$? En déduire une preuve de la conjecture de la question précédente.

4. Maximum de variables aléatoires exponentielles.

Dans cet exercice, $X_1, X_2, \dots$ est une suite de variables aléatoires indépendantes de loi $\text{Exp}(1)$, et on s'intéresse à la suite des maxima :

$$L_n = \max(X_1, X_2, \dots, X_n).$$

- (1) Écrire un programme qui trace le graphe de $n \mapsto \frac{L_n}{\log n}$ pour $n \in \llbracket 2, 5000 \rrbracket$. A-t-on une convergence presque sûre ?
- (2) Quelle est la fonction de répartition de L_n ? Montrer que

$$\sum_{n \geq 1} \mathbb{P}[L_n \leq (1 - \varepsilon) \log n] < +\infty$$

et que

$$\sum_{n \geq 1} \mathbb{P}[L_{\alpha_n} \geq (1 + \varepsilon) \log \alpha_n] < +\infty$$

pour tout $\varepsilon > 0$, et pour une suite croissante $(\alpha_n)_{n \geq 1}$ appropriée. En déduire une preuve de la conjecture de la question précédente. On pourra s'appuyer sur le lemme de Borel-Cantelli pour contrôler

$$\liminf_{n \rightarrow \infty} \frac{L_n}{\log n} \quad \text{et} \quad \limsup_{n \rightarrow \infty} \frac{L_{\alpha_n}}{\log \alpha_n},$$

et pour la limite supérieure de L_n (au lieu de L_{α_n}), on pourra utiliser la croissance de la suite $(L_n)_{n \geq 1}$.

- (3) Tracer maintenant le graphe de $n \mapsto L_n - \log n$ pour $n \in \llbracket 1, 5000 \rrbracket$. A-t-on une convergence presque sûre ?
- (4) Calculer la limite de $\mathbb{P}[L_n \leq \log n + t]$, et en déduire la convergence en loi de la suite $(L_n - \log n)_{n \geq 1}$. La loi limite est appelée *loi de Gumbel*.
- (5) Dessiner sur un même graphique la fonction de répartition empirique d'un échantillon de $N = 1000$ tirages de la variable $L_{1000} - \log 1000$, et la fonction de répartition de la loi de Gumbel.